

KLASIFIKACIJA

JELENA JOVANOVIĆ

Email: jeljov@gmail.com

Web: <http://jelenajovanovic.net>

PREGLED PREDAVANJA

- Šta je klasifikacija?
- Binarna i više-klasna klasifikacija
- Algoritmi klasifikacije
- Naïve Bayes (NB) algoritam
- Klasifikacija teksta primenom NB algoritma
 - Primer klasifikacije teksta korišćenjem WEKA-e
- Mere uspešnosti klasifikatora

ŠTA JE KLASIFIKACIJA?

- Zadatak određivanja klase kojoj neka instanca pripada
 - instanca je opisana vrednošću atributa;
 - skup mogućih klasa je poznat i dat
- Klase su date kao nominalne vrednosti, npr.
 - klasifikacija email poruka: spam, not-spam
 - klasifikacija novinskih članaka: politika, sport, kultura i sl.

BINARNA I VIŠE-KLASNA KLASIFIKACIJA


Zavisno od broja klasa, razlikujemo:

- *binarnu* klasifikaciju - postoje dve klase
- *više-klasnu* klasifikacija - postoji više klasa u koje instance treba razvrstati

Princip rada algoritma u oba slučaja je gotovo isti:

u slučaju postojanja više klasa, algoritam iterativno uči, tako da u svakoj iteraciji “nauči” da jednu od klasa razgraniči od svih ostalih

VIŠE-KLASNA KLASIFIKACIJA



ALGORITMI KLASIFIKACIJE

Postoje brojni pristupi/algoritmi za klasifikaciju:

- Logistička regresija
- Naïve Bayes
- Algoritmi iz grupe Stabala odlučivanja
- Algoritmi iz grupe Neuronskih mreža
- k-Nearest Neighbor (kNN)
- Support Vector Machines (SVM)
- ...

NAÏVE BAYES

ZAŠTO BAŠ NAÏVE BAYES?

Naïve Bayes (NB) se navodi kao algoritam koji treba među prvima razmotriti pri rešavanju zadataka klasifikacije

Razlozi:

- Jednostavan je
- Ima dobre performanse
- Vrlo je skalabilan
- Može se prilagoditi za gotovo bilo koji problem klasifikacije

Occam's Razor:

“Other things being equal, simple theories are preferable to complex ones”

PODSEĆANJE: BAYES-OVO PRAVILO

$$P(H|E) = P(E|H) * P(H) / P(E)$$

- H – hipoteza (*hypothesis*)
- E – opažaj (*evidence*) vezan za hipotezu H, tj. podaci na osnovu kojih bi trebalo da potvrdimo ili odbacimo hipotezu H
- P (H) – verovatnoća hipoteze H (*prior probability*)
- P (E) – verovatnoća opažaja tj. stanja na koje ukazuju prikupljeni podaci
- P (E | H) – (uslovna) verovatnoća opažaja E ukoliko važi hipoteza H
- P (H | E) – (uslovna) verovatnoća hipoteze H ukoliko imamo opažaj E

BAYES-OVO PRAVILO - PRIMER

Pretpostavite sledeće:

- jednog jutra ste se probudili sa povišenom temperaturom
- prethodnog dana ste čuli da je u gradu počela da se širi virusna infekcija, ali da je verovatnoća zaraze mala, svega 2.5%
- takođe ste čuli da je u 50% slučajeva virusna infekcija praćena povišenom temperaturom
- u vašem slučaju, povišena temperatura se javlja svega par puta u godini, tako da je verovatnoća da imate povišenu temp. 6.5%

Pitanje: kolika je verovatnoća da, pošto imate povišenu temp., da imate i virusnu infekciju?

BAYES-OVO PRAVILO - PRIMER

Teorija	Primer
Hipoteza (H)	Imate virusnu infekciju
P(H)	0.025
Opažaj (evidence - E)	Imate povišenu temperaturu
P(E)	0.065
(uslovna) verovatnoća opažaja E ukoliko važi hipoteza H: P(E H)	Verovatnoća da je virusna infekcija praćena povišenom temperaturom 0.50
(uslovna) verovatnoća hipoteze H ukoliko imamo opažaj E: P(H E)	Verovatnoća da pošto imate povišenu temp., da imate i virusnu infekciju ?

$$P(H|E) = P(E|H) * P(H) / P(E)$$

$$P(H|E) = 0.50 * 0.025 / 0.065 = 0.19$$

NAÏVE BAYES U KLASIFIKACIJI TEKSTA

NB je jedan od najčešće korišćenih algoritama za klasifikaciju teksta

Zadatak klasifikacije teksta: odrediti kojoj klasi (c) iz datog skupa klasa (C), dati tekst pripada

Na primer:

- tematska klasifikacija novinskih članaka
- klasifikacija tweet poruka prema iskazanom stavu (poz./neg.)

FORMIRANJE VEKTORA ATRIBUTA

Tekst koji je predmet klasifikacije se tretira kao prost skup reči (tzv. bag-of-words)

- Reči iz teksta su osnova za kreiranje atributa (features) sa kojima će NB algoritam raditi
- Postoji više načina da se reči iz teksta upotrebe za definisanje vektora atributa (feature vector) za klasifikaciju

FORMIRANJE VEKTORA ATRIBUTA

Pristup koji se pokazao kao posebno dobar:

- Estrahovati reči iz dokumenata koji čine skup za trening D , i formirati tzv. Rečnik R ;
- Za svaki dokument d iz skupa D definisati skup atributa (feature vector) na osnovu reči iz kojih se d sastoji:
 - Za svaku reč r_i iz dokumenta d uvodi se atribut x_i čija vrednost je indeks reči r_i u rečniku R ;
 - Atributi mogu biti kreirani za sve reči dokumenta d ili samo za one reči koje su značajne za dati zadatak klasifikacije

FORMIRANJE VEKTORA ATRIBUTA - PRIMER

Y (

I love this movie! It's sweet, but with satirical humor. The dialogue is great and the adventure scenes are fun... It manages to be whimsical and romantic while laughing at the conventions of the fairy tale genre. I would recommend it to just about anyone. I've seen it several times, and I'm always happy to see it again whenever I have a friend who hasn't seen it yet.

) = C



FORMIRANJE VEKTORA ATRIBUTA - PRIMER

Y (

I **love** this movie! It's **sweet**, but with **satirical** humor. The dialogue is **great** and the adventure scenes are **fun**... It manages to be **whimsical** and **romantic** while **laughing** at the conventions of the fairy tale genre. I would **recommend** it to just about anyone. I've seen it **several** times, and I'm always **happy** to see it **again** whenever I have a friend who hasn't seen it yet.

) = C



FORMIRANJE VEKTORA ATRIBUTA - PRIMER

Y

reči (r_i)	atributi (x_i)
$r_1 = \text{love}$	$x_1 = 04567$
$r_2 = \text{sweet}$	$x_2 = 14321$
$r_3 = \text{satirical}$	$x_3 = 14007$
...	
$r_{11} = \text{happy}$	$x_{11} = 02364$
$r_{12} = \text{again}$	$x_{12} = 00012$

$= C$



indeks reči r_i u
Rečniku R

NB U KLASIFIKACIJI TEKSTA

Ako je c klasa, a d dokument, verovatnoća da je upravo c klasa dokumenta d biće:

$$P(c|d) = P(d|c) * P(c) / P(d) \quad (1)$$

Za dati skup klasa C i dokument d , želimo da pronađemo onu klasu c iz skupa C koja ima najveću uslovnu verovatnoću za dokument d , što daje sledeću funkciju:

$$f = \operatorname{argmax}_{c \text{ iz } C} P(c|d) \quad (2)$$

Primenom Bayes-ovog pravila, dobijamo:

$$f = \operatorname{argmax}_{c \text{ iz } C} P(d|c) * P(c) \quad (3)$$

NB U KLASIFIKACIJI TEKSTA

$$f = \operatorname{argmax}_{c \text{ iz } C} P(d|c) * P(c) \quad (3)$$

Potrebno je odrediti verovatnoće $P(c)$ i $P(d|c)$

$P(c)$ se može *proceniti* relativno jednostavno: brojanjem pojavljivanja klase c u skupu dokumenata za trening D

$P(d|c)$ - verovatnoća da u klasi c zateknemo dokument d – nije tako jednostavno odrediti i tu uvodimo pretpostavke koje NB algoritam čine “naivnim”

NB U KLASIFIKACIJI TEKSTA

Kako odrediti $P(d|c)$?

- dokument d predstavljamo kao skup atributa (x_1, x_2, \dots, x_n)
- umesto $P(d|c)$ imaćemo $P(x_1, x_2, x_3, \dots, x_n|c)$
- da bi izračunali $P(x_1, x_2, x_3, \dots, x_n|c)$ uvodimo 2 naivne pretpostavke:
 - dokument d posmatramo kao prost skup reči (bag-of-words); tj. pozicija i redosled reči u tekstu se smatraju nevažnim
 - pojavljivanje određene reči u datoj klasi c je nezavisno od pojavljivanja neke druge reči u toj klasi

NB U KLASIFIKACIJI TEKSTA

Uvedene pretpostavke

- dovode do značajnog gubitka informacija koje iz podataka možemo da izvučemo, ali,
- omogućuju značajno jednostavnije računanje $P(x_1, x_2, \dots, x_n | c)$, a time i ceo problem klasifikacije

NB U KLASIFIKACIJI TEKSTA

Na osnovu uvedenih pretpostavki, $P(x_1, x_2, \dots, x_n | c)$ možemo da predstavimo kao proizvod individualnih uslovnih verovatnoća

$$P(x_1, x_2, \dots, x_n | c) = P(x_1 | c) * P(x_2 | c) * \dots * P(x_n | c)$$

Time dolazimo do opšte jednačine NB algoritma:

$$f = \operatorname{argmax}_c \text{ iz } c \quad P(c) * \prod_{i=1, n} P(x_i | c)$$

NB U KLASIFIKACIJI TEKSTA

Procena verovatnoća se vrši na osnovu skupa za trening, i zasniva na sledećim jednačinama:

$P(c) = \text{br. dok. klase } \mathbf{c} / \text{ukupan br. dok. u skupu za trening}$

$P(x_i | c) = \text{br. pojavljivanja reči } \mathbf{r}_i \text{ u dok. klase } \mathbf{c} / \text{ukupan br. reči iz rečnika } \mathbf{R} \text{ u dok. klase } \mathbf{c}$

OSOBI NE NB ALGORITMA

- Veoma brz i efikasan
- Najčešće daje dobre rezultate
 - često se pokazuje kao bolji ili bar podjednako dobar kao drugi, sofisticiraniji modeli
- Nije memorijski zahtevan
- Ima vrlo mali afinitet ka preteranom podudaranju sa podacima za trening (overfitting)
- Pogodan kada imamo malu količinu podataka za trening

OSOBI NE NB ALGORITMA

- “Otporan” na nevažne atribute
 - atributi koji su podjednako distribuirani kroz skup podataka za trening, pa nemaju veći uticaj na izbor klase
- Namenjen primarno za rad sa nominalnim atributima; u slučaju numeričkih atributa:
 - koristiti raspodelu verovatnoća atributa (tipično Normalna raspodela) za procenu verovatnoće svake od vrednosti atributa
 - uraditi diskretizaciju vrednosti atributa

PRIMER PRIMENE NB ALGORITMA
KORIŠĆENJEM WEKA FRAMEWORK-A

PRIMER PRIMENE NB ALGORITMA KORIŠĆENJEM WEKA FRAMEWORK-A

Primer je preuzet iz GitHub projekta TMWeka:

<https://github.com/jmgomezh/tmweka>

i raspoloživ je na sledećoj adresi:

<https://github.com/jmgomezh/tmweka/tree/master/FilteredClassifier>

U okviru TMWeka projekta, ima jos nekoliko interesantnih primera klasifikacije teksta primenom ML algoritama

MERE USPEŠNOSTI KLASIFIKATORA

Neke od najčešće korišćenih metrika:

- Matrica zabune (Confusion Matrix)
- Tačnost (Accuracy)
- Preciznost (Precision) i Odziv (Recall)
- F mera (F measure)
- Površina ispod ROC krive (Area Under the Curve - AUC)

MATRICA ZABUNE (CONFUSION MATRIX)

Služi kao osnova za računanje mera performansi (uspešnosti) algoritama klasifikacije

		Predicted Class	
		Yes	No
Actual Class	Yes	TP	FN
	No	FP	TN

TP = True Positive

FP = False Positive

TN = True Negative

FN = False Negative

TAČNOST (ACCURACY)

Tačnost (Accuracy) predstavlja procenat slučajeva (instanci) koji su uspešno (korektno) klasifikovani

$$\text{Accuracy} = (TP + TN) / N$$

gde je:

- TP – True Positive; TN – True Negative
- N – ukupan broj uzoraka (instanci) u skupu podataka

		Predicted Class	
		Yes	No
Actual Class	Yes	TP	FN
	No	FP	TN

TAČNOST (ACCURACY)

U slučaju vrlo neravnomerne raspodele instanci između klasa (tzv. skewed classes), ova mera je nepouzdana

Npr. u slučaju klasifikacije poruka na spam vs. not-spam, možemo imati skup za trening sa 0.5% spam poruka

Ako primenimo “klasifikator” koji svaku poruku svrstava u not-spam klasu, dobijamo tačnost od 99.5%

Očigledno je da ova metrika nije pouzdana i da su u slučaju skewed classes potrebne druge metrike

PRECIZNOST (PRECISION) I ODZIV (RECALL)

Precision = TP / no. predicted positive = TP / (TP + FP)

Npr. od svih poruka koje su *označene kao spam* poruke, koji procenat čine poruke koje su stvarno spam


Recall = TP / no. actual positive = TP / (TP + FN)

Npr. od svih poruka koje su *stvarno spam* poruke, koji procenat poruka je detektovan/klasifikovan kao spam

		Predicted Class	
		Yes	No
Actual Class	Yes	TP	FN
	No	FP	TN

PRECIZNOST I ODZIV

U praksi je nužno praviti kompromis između ove dve mere: ako želimo da povećamo Odziv, smanjićemo Preciznost, i obrnuto.



F MERA (F MEASURE)

F mera kombinuje Preciznost i Odziv i omogućuje jednostavnije poređenje dva ili više algoritama

$$F = (1 + \beta^2) * Precision * Recall / (\beta^2 * Precision + Recall)$$

Parametar β kontroliše koliko više značaja će se pridavati Odzivu u odnosu na Preciznost

U praksi se najčešće koristi tzv. F1 mera („balansirana“ F mera) koja daje podjednak značaj i Preciznosti i Odzivu:

$$F1 = 2 * Precision * Recall / (Precision + Recall)$$

POVRŠINA ISPOD ROC KRIVE


Površina ispod ROC* krive – Area Under the Curve (AUC):

- meri diskriminacionu moć klasifikatora tj. sposobnost da razlikuje instance koje pripadaju različitim klasama
- primenjuje se za merenje performansi binarnih klasifikatora
- vrednost za AUC se kreće u intervalu 0-1
- za metodu slučajnog izbora važi da je $AUC = 0.5$; što je AUC vrednost klasifikatora > 0.5 , to je klasifikator bolji
 - 0.7–0.8 se smatra prihvatljivim; 0.8–0.9 jako dobrim; sve > 0.9 je odlično

*ROC = Receiver Operating Characteristic;

http://en.wikipedia.org/wiki/Receiver_operating_characteristic

POVRŠINA ISPOD ROC KRIVE



ZAHVALNICE I PREPORUKE

PREPORUKE I ZAHVALNICE

MACHINE LEARNING @ STANFORD

- Coursera: <https://www.coursera.org/course/ml>
- Stanford YouTube channel:
http://www.youtube.com/view_play_list?p=A89DCFA6ADACE599

MACHINE LEARNING @ Carnegie Mellon University

- Predavanja Andrew W. Moore-a, posebno, lekcija na temu Bayes-ovog pravila i Naïve Bayes algoritma:
http://www.autonlab.org/tutorials/prob_and_naive_bayes.pdf

PREPORUKA

DATA STORIES PODCASTS

- <http://datastori.es/>
- posebno podcast #27 na temu “Big Data Skepticism”
- studija pomenuta u podcast-u #27 na temu predikcije karakteristika korisnika FB-a, samo na osnovu njihovih FB Likes:

<http://www.pnas.org/content/early/2013/03/06/1218772110.full.pdf>

(Anonimni) upitnik za vaše kritike,
komentare, predloge:

<http://goo.gl/cqdp3l>